

IDENTIFIKASI GANGGUAN DI SALURAN TRANSMISI 115 kV MENGGUNAKAN METODE TWD DAN *RECURRENT NEURAL NETWORKS*

Sahala Tua¹⁾, Azriyenni Azhari Zakri²⁾, Dian Yayan Sukma³⁾

^{1,2)}Program Studi Teknik Elektro S1, Fakultas Teknik Universitas Riau
Kampus Bina Widya, Jl. H. R. Soebrantas Km. 12,5 Simpang Baru, Panam
Pekanbaru 28293

Email: sahalatua@student.unri.ac.id; azriyenni@eng.unri.ac.id

ABSTRACT

The transmission system is the connecting part between the power plant and the distribution system and, will be forwarded to the load. When the fault occurred in the transmission line, it can cause a cut off in the supply of electrical energy to the load, causing losses to consumers. Therefore, a method is needed to identify fault accurately and quickly by reducing search time and speeding up the repair process. In this article, the identification of fault to be carried out is the classification and estimation of fault locations in the 115 kV transmission system. The method to be implemented is Discrete Wavelet Transformation (DWT) and Recurrent Neural Networks (RNN) using the type of Elman. This study applied the DWT and RNN methods to identify short circuit fault that occurs in the transmission line. DWT is aimed at extracting information of transient signals for each phase current and zero sequence current in one cycle when the fault occurred. RNN classification is used to detect a fault with each phase and ground and RNN to estimate the location of fault that occurs in the transmission line. Training and testing data generated by running simulations of each type of short circuit fault using Simulink Matlab R2016a with variation parameters; location point of fault, fault resistance and initial angle of fault. Short circuit fault applied in the transmission line on Simulink model of the Bus LK to Bus BK at a voltage of 115 kV and a line length of 63.3 km. The results obtained are a classification of fault with an accuracy of 100% and, estimation of fault locations with the highest average error value is 1.418568%.

Keywords: DWT, estimation of fault, RNN Elman, short circuit.

I. PENDAHULUAN

Pada sistem transmisi merupakan bagian penghubung antara pusat pembangkit tenaga listrik dengan sistem distribusi yang akan diteruskan ke pusat-pusat beban. Ketika terjadi gangguan pada saluran transmisi dapat menyebabkan terputusnya suplai energi listrik yang mengarah ke beban sehingga menyebabkan kerugian bagi konsumen dengan terganggunya kegiatan produksi.

Gangguan hubung singkat merupakan gangguan yang sering terjadi pada saluran transmisi. Gangguan hubung singkat tersebut dapat berupa gangguan hubung singkat asimetris dan gangguan hubung singkat simetris. Gangguan hubung singkat asimetris diantaranya gangguan satu fasa ke tanah (LG), fasa ke fasa (LL) dan dua fasa

ke tanah (LLG). Tetapi gangguan simetris adalah gangguan 3 fasa (LLL). Setiap karakteristik arus dan tegangan pada saat terjadi gangguan hubung singkat berbeda tergantung dengan jenis gangguan hubung singkat yang terjadi. Oleh karena itu, pada saat terjadi hubung singkat yang terjadi di saluran transmisi harus diketahui jenisnya terlebih dahulu dan selanjutnya akan dilakukan estimasi terhadap lokasi gangguan yang terjadi.

Pada penelitian ini akan membahas langkah-langkah melakukan klasifikasi jenis gangguan dan estimasi lokasi gangguan hubung singkat menggunakan metode transformasi wavelet dan *Recurrent Neural Networks* (RNN). Perbedaan antara transformasi wavelet dengan transformasi

fourier yaitu pada informasinya yang terbatas hanya pada domain frekuensi, sedangkan informasi yang diperoleh transformasi wavelet berupa domain frekuensi dan waktu. Maka oleh dari itu transformasi wavelet lebih baik daripada transformasi *Fourier*. Transformasi Wavelet Diskrit (TWD) adalah transformasi wavelet yang digunakan pada penelitian ini, berfungsi untuk mendapatkan informasi dari sinyal transien saat gangguan hubung singkat mulai terjadi.

Penggunaan untuk wavelet bisa digunakan pada sistem perlindungan pada transformator daya (Isyadi & Mardiana, 2007). Pengolahan hasil TWD akan dimanfaatkan sebagai masukan dalam menggunakan Jaringan Saraf Tiruan (JST) untuk mengklasifikasi jenis dan estimasi lokasi gangguan hubung singkat. Perolehan fungsi yang digunakan pada JST dengan menggunakan pelatihan RNN yang terdapat pada *software* Matlab. Maka JST digunakan untuk klasifikasi jenis gangguan dan estimasi lokasi gangguan hubung singkat lebih mudah dilakukan dan memiliki tingkat keakuratan yang juga tinggi. Klasifikasi jenis gangguan dan estimasi lokasi gangguan hubung singkat pada saluran transmisi 115 kV dilakukan melalui suatu simulasi menggunakan perangkat lunak Matlab R2016a.

Muhammad Otong dkk, memaparkan untuk mendeteksi gangguan yang akurat pada saluran transmisi dan cepat untuk mengurangi waktu pencarian sehingga mempercepat proses. Dengan menggunakan kombinasi metode Transformasi *Park* dan *Adaptive Neuro Fuzzy Inference System* (ANFIS), dapat dideteksi jarak lokasi gangguan secara langsung setelah terjadinya gangguan dengan cara menganalisa gelombang berjalan yang berupa arus dan tegangan yang kemudian akan ditransformasikan *Park* pada kedua ujung saluran yang menghasilkan perbedaan waktu pada tiap ujung saluran dikarenakan adanya perbedaan jarak yang ada. Perbedaan waktu ini akan di input kedalam ANFIS untuk mendapatkan jarak lokasi gangguan (Otong, Alimuddin, & B, 2017).

Menurut Neethu A. S dan Angel T. S telah melakukan pengolahan data yang dihasilkan dari TWD yang mengolah sinyal gangguan (*transient*) sebagai masukan *Artificial Neural Networks* (ANN) dengan jenis *backpropagation*. Teknik ANN dengan jenis *backpropagation* dengan TWD *mother* wavelet tipe *daubechies* orde 4 (dB4) dari koefisien detail level 5 lebih akurat dalam menentukan jenis gangguan dan lokasi gangguan (A.S & T.S, 2017).

Selanjutnya menurut Ahmed Saber dkk., telah mengusulkan penerapan TWD dengan *mother* wavelet tipe *daubechies* orde 4 (dB4) dengan frekuensi sampling 50 kHz dimana pada penerapan frekuensi sampling mendapatkan nilai dalam satu siklus yaitu 1000 *samples* dan SVM. Penjumlahan nilai absolut dari koefisien detail level 8 dan 9 digunakan sebagai masukan untuk SVM. Hasil yang didapatkan bahwa metode ini mampu mengklasifikasi gangguan pada saluran transmisi paralel dengan benar (Saber, Emam, & Amer, 2016).

Dan menurut Syukri Darmawan, Sandy Ahmad dan Azriyenni, telah melakukan pengolahan data yang dihasilkan dari TWD yang mengolah sinyal arus gangguan pada satu siklus saat terjadi gangguan sebagai masukan SVM (*Support Vector Machine*) dan ANFIS. SVM yang digunakan adalah jenis *Kernel Gausisan* dan pada perancangan ANFIS untuk estimasi gangguan menggunakan jenis fungsi keanggotaan *generalized bell* dan *gauss* sedangkan TWD menggunakan *mother* wavelet tipe *daubechies* orde 4 (dB4) dari koefisien detail level 8 dan 9 untuk menentukan lokasi gangguan (Darmawan & Azriyenni, 2018; Ahmad & Azriyenni, 2019).

Berdasarkan penelitian yang terdahulu yang berkaitan tentang identifikasi gangguan pada saluran transmisi tenaga listrik menggunakan konsep teknik cerdas. Identifikasi gangguan pada saluran transmisi tenaga listrik mencakup tentang klasifikasi gangguan dan estimasi gangguan dengan jenis gangguan hubung singkat simetris (gangguan hubung singkat satu fasa ke tanah, gangguan hubung singkat dua fasa, gangguan hubung singkat dua fasa ke tanah) dan asimetris (gangguan hubung singkat tiga fasa). Maka penelitian ini pula menggunakan konsep teknik cerdas dengan mengusulkan penerapan metode TWD dan *Recurrent Neural Networks* (RNN) di saluran transmisi 115 kV dan menerapkan keluaran pada RNN membandingkan nilai *error* terkecil berdasarkan MAPE dan durasi pelatihan terkecil. Model ini diharapkan meningkatkan prediksi gangguan dengan membangun struktur baru yaitu jenis RNN tipe Elman yang akan dijalankan menggunakan perangkat lunak Matlab/Simulink versi 20016a.

Transformasi Wavelet Diskrit

Transformasi wavelet memiliki kemampuan untuk menganalisa berbagai jenis gangguan dengan informasi yang diperoleh daripada domain

frekuensi dan domain waktu. Transformasi wavelet sangat berguna dalam mendeteksi dan mengolah berbagai data gangguan karena sensitif terhadap ketidakteraturan sinyal (Misiti et al., 2006).

Transformasi wavelet dapat dibagi menjadi dua jenis, yaitu transformasi wavelet kontinu dan transformasi wavelet diskrit. wavelet kontinu digunakan untuk menghitung transisi sinyal dari sinyal modular kapan saja ke skala yang diinginkan. Skala jendela memiliki mode yang dapat dimodifikasi. Dengan memberikan gelombang $f(t)$, transformasi wavelet kontinu dapat dihitung sebagai berikut (Rucka & Wilde, 2006; Jamali & Ghaffarzadeh, 2011).

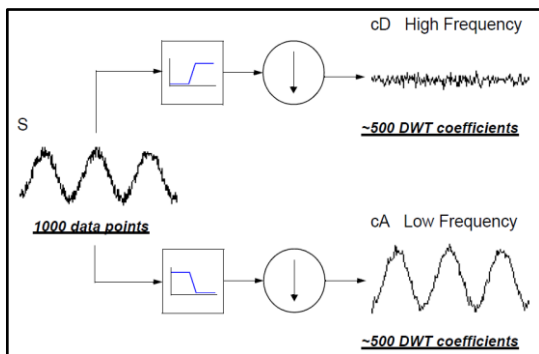
$$TWK(f, a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \varphi^* \left(\frac{t-b}{a} \right) dt \quad (1)$$

Dimana a dan b adalah konstanta skala dan konstanta transisi (pergeseran waktu), TWK (f, a, b) adalah koefisien TWK, dan φ adalah wavelet buatan. Sinyal input $f(t)$ telah disusun ulang menggunakan parameter perpindahan dan ekspansi waktu untuk skala yang tepat.

Transformasi wavelet diskrit dianggap sebagai implementasi yang relatif mudah dibandingkan dengan transformasi wavelet kontinu. Koefisien gelombang TWD dapat diperoleh dengan menerapkan TWD sebagai persamaan berikut (Mosavi & Tabatabaei, 2014).

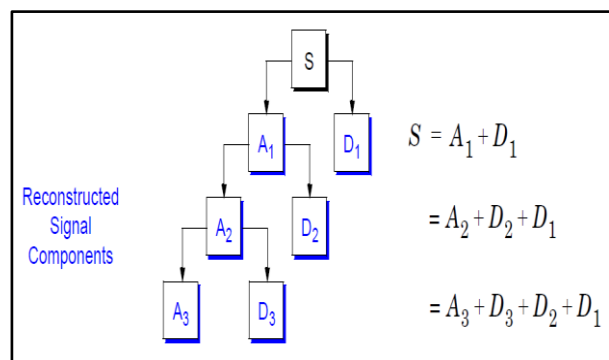
$$TWD(f, m, k) = \frac{1}{\sqrt{a_0^m}} \sum_k f(k) \varphi^* \left[\frac{n - ka_0^m}{a_0^m} \right] \quad (2)$$

Dimana parameter a dan b dalam persamaan (6) diganti sebagai a_0^m , ka_0^m , k dan m adalah bilangan bulat positif. TWD membagi (dekomposisi) sinyal gelombang menjadi dua bagian dengan menggunakan teknik pemfilteran dan operasi *downsampling*.



Gambar 1. Diagram skema pengolahan sinyal dengan TWD (Misiti et al., 2016)

Gambar 1 memperlihatkan bahwa gelombang sinyal input dibagi menjadi dua bagian, sinyal frekuensi rendah dikenal sebagai aproksimasi dan bagian frekuensi tinggi sebagai detail. Pada transformasi wavelet digunakan *mother wavelet* dalam mengolah sinyal asli. *Mother wavelet* terdiri dari berbagai jenis seperti Haar, Daubechies, Coiflets, Symlets, dll. *Mother wavelet* yang paling banyak digunakan adalah daubechies yang biasa ditulis dbN , di mana N adalah orde, dan db menunjukkan nama *mother wavelet* Daubechies (Borghetti, Bosetti, & Paolone, 2008).



Gambar 2. Proses dekomposisi pada TWD (Misiti et al., 2016)

Gambar 2 menampilkan proses dekomposisi pada TWD dengan keluaran berupa aproksimasi yang dijadikan kembali sebagai masukan TWD untuk level berikutnya. Sinyal pertama dikirim ke filter *high-pass* dan filter *low-pass* lalu bagian dari setiap keluaran diambil sebagai sampel.


RNN tipe Elman

Jaringan *recurrent* sederhana merupakan variasi dari *Multi-Layer Perceptron* sering disebut juga sebagai jaringan Elman karena ditemukan oleh Jeff Elman. Perbedaan utama yang terdapat pada struktur ini adalah adanya beberapa unit yang berdekatan dengan layer masukan yang terhubung ke lapisan tersembunyi seperti masukan unit yang lain. Unit-unit tersebut mengandung isi dari salah satu layer yang ada ketika pola sebelumnya dilatih.

RNN Elman terdiri atas satu atau lebih lapisan tersembunyi. Lapisan pertama memiliki bobot-bobot yang diperoleh dari lapisan masukan, setiap lapisan akan menerima bobot dari lapisan sebelumnya. Jaringan ini menggunakan fungsi aktivasi *sigmoid biner*, *sigmoid bipolar* untuk lapisan tersembunyi masukan dan fungsi *linear* untuk lapisan keluaran.

Pada jaringan Elman ini, mempunyai fungsi aktivasi yang dapat berupa sembarang fungsi, baik yang kontinu maupun diskontinyu. Delay yang terjadi pada hubungan antara lapisan masukan dengan lapisan tersembunyi pertama pada waktu sebelumnya (t-1) dapat digunakan untuk saat ini (t) (Kusumadewi, 2003).

Keunikan RNN *Elman* adalah adanya koneksi umpan balik yang membawa informasi gangguan pada saat masukan sebelumnya yang akan diakomodasikan bagi masukan berikutnya dapat dilihat pada Gambar 10. Karena sifat dari umpan balik ini, unit dapat terus mendaur ulang informasi melalui jaringan hingga langkah-langkah beberapa waktu, dan dengan demikian menemukan representasi waktu yang abstrak. Oleh karena itu jaringan saraf RNN tidak hanya merekam data masa lalu (Haykin, 2001).



Gambar 3. Arsitektur RNN tipe Elman

Sebuah RNN sederhana (Elman, 1990) memiliki umpan balik aktivasi yang mewujudkan memori jangka pendek. Lapisan diperbarui tidak hanya dengan masukan eksternal jaringan tetapi juga dengan aktivasi dari propagasi maju sebelumnya. Umpan balik ini dimodifikasi dengan satu set bobot untuk memungkinkan adaptasi otomatis melalui belajar misalnya *Backpropagation* (BP).

Mean Absolute Percentage Error (MAPE)

Untuk validasi keandalan suatu proses prakiraan dapat menggunakan MAPE (*Mean Absolute Percentage Error*). Cara mendapatkan nilai MAPE yaitu dengan menghitung kesalahan absolut pada tiap periode dibagi dengan nilai observasi yang nyata untuk periode itu. Kemudian, rata-rata kesalahan persentase absolut tersebut, seperti persamaan 2.27 dibawah ini (Sari, 2016).

Hasil perhitungan nilai MAPE digunakan untuk menentukan baik atau tidaknya prediksi yang dihasilkan. Kemampuan prediksi atau peramalan sangat baik jika memiliki nilai MAPE dibawah 10%. Serta memiliki peramalan yang baik jika memiliki nilai MAPE dibawah 20% (Margi,2015). Ketika nilai peramalan yang dihasilkan baik, maka jaringan RNN tipe Elman yang dibangun adalah baik.

$$MAPE = \frac{\sum \frac{|y_i - y'_i|}{y_i}}{n} \times 100\% \quad (3)$$

dimana :

y_i = Nilai target sebenarnya

y'_i = Nilai keluaran prediksi


n = Jumlah data

II. METODA PENELITIAN

Pada penulisan artikel ini dilakukan penelitian dengan data sistem transmisi tenaga listrik 115 kV, kemudian dilakukan pemodelan dari data sistem transmisi tenaga listrik tersebut menggunakan Matlab/*Simulink*. Selanjutnya dilakukan simulasi gangguan hubung singkat pada pemodelan tersebut dengan variasi berupa jenis gangguan, lokasi gangguan, sudut mula gangguan (*Fault Inception Angle/ FIA*) dan resistansi gangguan. Kemudian data-data yang diperoleh dari simulasi gangguan hubung singkat berupa sinyal arus gangguan akan diolah menggunakan TWD. Hasil olahan dari TWD digunakan sebagai input pada RNN tipe Elman untuk klasifikasi dan estimasi lokasi gangguan.

Sistem transmisi tenaga listrik yang digunakan sebagai objek penelitian berupa saluran transmisi yang dimulai dari Gardu Induk LK, dan BK. Sistem ini membeli daya untuk memenuhi setiap beban yang dimiliki setiap bus. Pembelian daya ini merupakan berasal dari Grid CPI yang akan menyalurkan ke setiap bus di saluran transmisi 115 kV. Grid CPI yang akan diterima dari bus LK dan

bus BK. Gangguan diletakkan pada saluran transmisi antara bus LK dan BK yang memiliki panjang saluran sebesar 63,3 km. Gambar 4 menampilkan *single line* diagram pada sistem transmisi objek penelitian. Terdapat 2 bus dengan LK, dan BK.



Gambar 4. *Single line* diagram sistem transmisi tenaga listrik objek penelitian

Sinyal arus yang diperoleh dari hasil simulasi gangguan menggunakan Matlab/*Simulink* dengan frekuensi *sampling* 60 kHz akan diolah menggunakan fungsi TWD yang merupakan fitur pada Matlab. Kemudian diambil data arus selama satu siklus setelah gangguan terjadi. Kemudian data arus gangguan tersebut diolah menggunakan TWD setelah itu keluaran dari TWD menjadi data masukan untuk RNN tipe Elman untuk menentukan klasifikasi dan estimasi lokasi gangguan. Urutan dekomposisi wavelet dengan frekuensi *sampling* 60 kHz dapat dilihat pada tabel 1.

Tabel 1. Urutan dekomposisi wavelet dengan frekuensi *sampling* 60 kHz

Level	Approximation	Detail
1	0 – 15 kHz	15 – 30 kHz
2	0 – 7,5 kHz	7,5 – 15 kHz
3	0 – 3,75 kHz	3,75 – 7,5 kHz
4	0 – 1,875 kHz	1,875 – 3,75 kHz
5	0 – 937,5 Hz	937,5 – 1875 Hz
6	0 – 468,75 Hz	468,75 – 937,5 Hz
7	0 – 234,375 Hz	234,37 – 468,75 Hz
8	0 – 117,1875 Hz	117,18 – 234,3 Hz
9	0 – 58,59375 Hz	58,593 – 117,18 Hz

Penentuan *mother wavelet* yang digunakan dalam proses TWD terhadap sinyal arus adalah *daubechies* orde 4 karena menghasilkan akurasi klasifikasi yang lebih baik dan nilai *error* yang lebih

kecil pada estimasi lokasi gangguan dibandingkan *mother wavelet* lainnya (Ray & Mishra, 2016) dan sangat efektif untuk menganalisa terhadap sinyal transien (Saber, Emam, & Amer, 2016).

Data tegangan dan arus selama satu siklus setelah gangguan terjadi hasil keluaran TWD pada detail level 8 (D8) dan detail level 9 (D9) dihitung nilai RMS untuk digunakan sebagai masukan pada RNN tipe Elman.

Kemudian dilakukan pemilihan struktur terhadap hasil RNN tipe Elman yang paling baik pada RNN tipe Elman klasifikasi dan RNN tipe Elman estimasi lokasi gangguan. Selanjutnya dilakukan pengujian kembali terhadap RNN tipe Elman yang telah dipilih dengan masukan yang berbeda dari data pelatihan dan pengujian RNN tipe Elman seperti terlihat pada Tabel 2.


Dihitung akurasi dan *error* yang didapat dari hasil pengujian menggunakan RNN tipe Elman klasifikasi dan estimasi lokasi gangguan yang telah dipilih.

Tabel 2. Parameter simulasi untuk pengujian RNN tipe Elman klasifikasi dan estimasi lokasi gangguan

Identifikasi	Gangguan	L (%)	R (Ω)	D (°)
Klasifikasi dan Estimasi	FT	1,6, 5,6, 9,6, ..., 93,6, 97.6	45	65
	FF			
	FFT			
	FFF			

Perancangan RNN tipe Elman untuk Klasifikasi Gangguan

RNN tipe Elman klasifikasi jenis gangguan dibuat dengan menggunakan RNN tipe Elman yang mengklasifikasi gangguan pada setiap fasa dan *tanah* yang bekerja secara paralel. Ketika ada gangguan pada suatu fasa, maka RNN tipe Elman tersebut akan memberikan informasi berupa adanya gangguan pada fasa tersebut. Begitu juga jika terjadi gangguan ke tanah, maka RNN tipe Elman akan membaca melalui sinyal arus urutan nol dan memberikan informasi adanya gangguan sesuai dengan nilai arus urutan nol yang dilatihkan pada RNN tipe Elman. Dengan menggabungkan seluruh informasi yang didapat dari klasifikasi gangguan yang terjadi pada setiap fasa dan *tanah* menggunakan RNN tipe Elman maka kita dapat mengetahui gangguan hubung singkat yang terjadi pada saluran transmisi. Struktur RNN tipe Elman untuk klasifikasi gangguan dapat dilihat pada Gambar 5.



Gambar 5. Struktur RNN tipe Elman klasifikasi gangguan

Gambar 5 merupakan struktur RNN tipe Elman untuk klasifikasi gangguan terdiri dari data masukan, lapisan tersembunyi, dan lapisan keluaran. Output yang dihasilkan adalah informasi berupa ada atau tidaknya gangguan pada fasa dan tanah.

Pada penelitian ini RNN tipe Elman klasifikasi gangguan diberikan masukan berupa variasi nilai RMS sinyal arus koefisien D8 dan D9 dari setiap hasil simulasi. Dimana masukan tersebut divariasikan yaitu:

1. 2 RMS koefisien detail sinyal arus fasa A
2. 2 RMS koefisien detail sinyal arus fasa B
3. 2 RMS koefisien detail sinyal arus fasa C
4. 2 RMS koefisien detail sinyal arus urutan nol

Untuk masing-masing RNN tipe Elman yang mengklasifikasi gangguan pada fasa A, B, dan C yang digunakan sebagai masukan adalah sampel arus gangguan masing-masing fasa. Untuk klasifikasi gangguan pada *tanah* yang akan digunakan sebagai masukan adalah sampel arus urutan nol.

Perancangan RNN tipe Elman untuk Estimasi Lokasi Gangguan

RNN tipe Elman estimasi lokasi gangguan dibuat untuk memperkirakan lokasi gangguan pada masing – masing jenis gangguan dan memberikan hasil keluaran berupa jarak lokasi gangguan. Setiap jenis gangguan memiliki struktur RNN tipe Elman estimasi lokasi gangguan yang berbeda. Adapun gangguan yang disimulasikan berupa gangguan FT (AG, BG, CG), FF (AB, AC, BC), FFT (ABG, ACG, BCG) dan FFF (ABC).

Pada perancangan RNN tipe Elman estimasi lokasi gangguan ini, akan dilakukan perancangan dengan memvariasikan masukan pada RNN tipe Elman. Pada RNN tipe Elman ini membuat dua struktur yaitu RNN 1 dan RNN 2 dengan perbedaan nilai Ir_dec RNN 1 adalah 0,6 dan nilai Ir_dec RNN 2 adalah 0,7, yang bertujuan untuk mendapatkan dan memilih hasil akurasi dan durasi pelatihan yang lebih baik dan cepat untuk pelatihan RNN tipe Elman estimasi lokasi gangguan. Proses pelatihan dilakukan sebanyak 100 kali iterasi dengan nilai toleransi *error* pelatihan adalah 0,000001. Struktur RNN tipe Elman untuk estimasi gangguan dapat dilihat pada Gambar 6.

Gambar 6 merupakan struktur RNN tipe Elman untuk estimasi lokasi gangguan. RNN tipe Elman untuk estimasi lokasi gangguan terdiri dari data masukan, lapisan tersembunyi, dan lapisan keluaran.. Output yang dihasilkan adalah informasi berupa jarak lokasi gangguan.

Pada penelitian ini RNN tipe Elman estimasi lokasi gangguan diberikan 6 masukan, yang berupa nilai RMS koefisien D8 dan D9 dari sinyal arus setelah gangguan pada setiap fasa. Masukan dari RNN tipe Elman estimasi lokasi gangguan dapat dirumuskan sebagai berikut :

$$X_{FL} = [ID8_A, ID9_A, ID8_B, ID9_B, ID8_C, ID9_C]$$

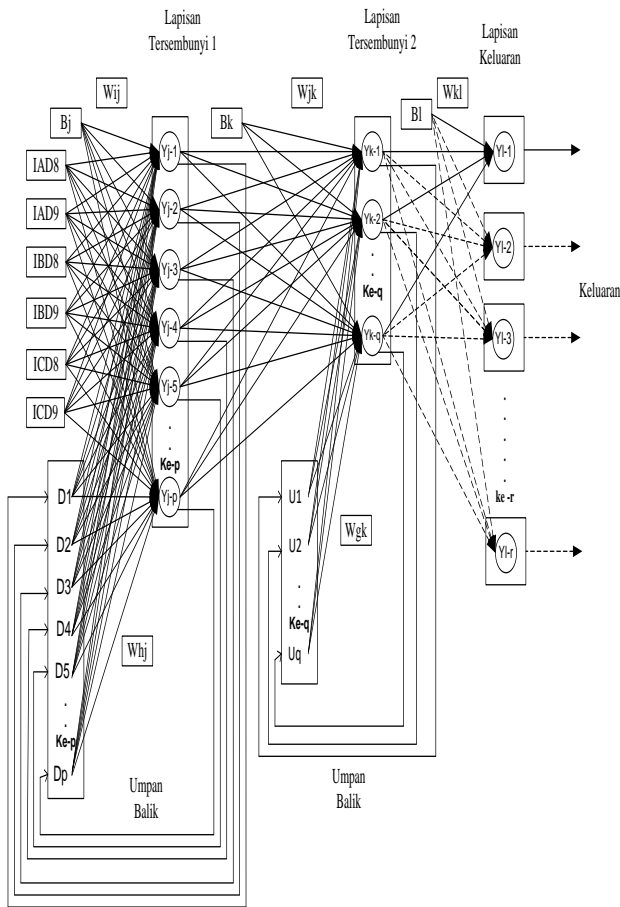
Dimana :

X_{FL} = Masukan RNN tipe Elman estimasi lokasi gangguan

$ID8_i$ = Nilai RMS koefisien D8 arus setelah gangguan

$ID9_i$ = Nilai RMS koefisien D9 arus setelah gangguan

i = Fasa A, B, C



Gambar 6. Struktur RNN tipe Elman estimasi lokasi gangguan

III. HASIL DAN PEMBAHASAN

Setelah dilakukan pelatihan dan pengujian pada berbagai jenis RNN tipe Elman klasifikasi dan estimasi lokasi gangguan, selanjutnya dilihat hasil keluaran pada masing – masing RNN tipe Elman. RNN tipe Elman yang akan digunakan dipilih berdasarkan keluaran dari RNN tipe Elman tersebut, yaitu dengan cara melihat nilai MAPE dan durasi pelatihan yang terkecil pada klasifikasi serta estimasi lokasi gangguan dari masing-masing RNN tipe Elman.

A. Klasifikasi Gangguan

Setelah dilakukan pelatihan dan pengujian pada berbagai jenis RNN tipe Elman klasifikasi maka pemilihan kode jaringan berdsarkan nilai MAPE terkecil dan durasi waktu pelatihan. Maka dari itu kita dapat memilih struktur RNN yang paling cocok untuk melakukan klasifikasi gangguan maka dapat dilihat pada Tabel 3.

Tabel 3. Struktur RNN tipe Elman yang digunakan untuk klasifikasi dan estimasi lokasi gangguan

Jaringan RNN tipe Elman	Kode Jaringan	
	MAPE (%)	Waktu
Klasifikasi Gangguan Fasa A	FCA2	FCA2
Klasifikasi Gangguan Fasa B	FCB1	FCB2
Klasifikasi Gangguan Fasa C	FCC2	FCC2
Klasifikasi Gangguan Tanah	FCG1	FCG1
Estimasi Lokasi Gangguan AG	FLAG2	FLAG2
Estimasi Lokasi Gangguan BG	FLBG1	FLBG2
Estimasi Lokasi Gangguan CG	FLCG2	FLCG1
Estimasi Lokasi Gangguan AB	FLAB1	FLAB2
Estimasi Lokasi Gangguan AC	FLAC2	FLAC2
Estimasi Lokasi Gangguan BC	FLBC1	FLBC2
Estimasi Lokasi Gangguan ABG	FLABG1	FLABG2
Estimasi Lokasi Gangguan ACG	FLACG2	FLACG2
Estimasi Lokasi Gangguan BCG	FLBCG2	FLBCG2
Estimasi Lokasi Gangguan ABC	FLABC2	FLABC2

B. Estimasi Lokasi Gangguan dengan Nilai MAPE Terkecil

Pada RNN tipe Elman klasifikasi gangguan dapat menentukan adanya gangguan pada masing – masing fasa dan tanah secara benar sesuai dengan jenis gangguan yang terjadi, sehingga akurasi RNN tipe Elman klasifikasi gangguan adalah 100 % tanpa ada satupun *error*. Sedangkan RNN tipe Elman yang digunakan estimasi lokasi gangguan berdasarkan nilai MAPE terkecil dapat dilihat pada Tabel 5 pada setiap jenis gangguan dapat dihitung nilai *error* dari hasil RNN tipe Elman.

Tabel 5. Struktur RNN tipe Elman yang digunakan untuk klasifikasi dan estimasi lokasi gangguan berdasarkan MAPE

Jenis Gangguan	Error (%)		
	MAPE	Maksimum	Minimum
Struktur RNN 1			
AG	0,245137	0,241118	0,000029
BG	0,504459	0,378000	0,004000
CG	0,321504	0,207000	0,000000
AB	0,282843	0,261000	0,000000
AC	0,892839	0,306349	0,006151

BC	1,017433	0,362200	0,002000
ABG	0,605522	0,250963	0,000912
ACG	0,326534	0,305512	0,001058
BCG	0,502179	0,305233	0,002017
ABC	0,629717	0,270158	0,004765

B. Estimasi Lokasi Gangguan dengan Nilai MAPE Terkecil

Pada RNN tipe Elman klasifikasi gangguan dapat menentukan adanya gangguan pada masing – masing fasa dan tanah secara benar sesuai dengan jenis gangguan yang terjadi, sehingga akurasi RNN tipe Elman klasifikasi gangguan adalah 100 % tanpa ada satupun *error*. Dan RNN tipe Elman yang digunakan estimasi lokasi gangguan berdasarkan nilai durasi pelatihan terkecil dapat dilihat pada Tabel 6 pada setiap jenis gangguan dapat dihitung nilai *error* dari hasil RNN tipe Elman.

Tabel 6. Struktur RNN tipe Elman yang digunakan untuk klasifikasi dan estimasi lokasi gangguan berdasarkan durasi pelatihan

Jenis Gangguan	Error (%)		
	MAPE	Maksimum	Minimum
	Struktur RNN 2		
AG	0,245137	0,241118	0,000029
BG	0,622443	0,281476	0,281476
CG	0,328350	0,264986	0,264986
AB	0,680925	0,412825	0,000929
AC	0,892839	0,306349	0,006151
BC	0,386365	0,202113	0,000795
ABG	1,418568	0,430777	0,006889
ACG	0,326534	0,305512	0,001058
BCG	0,502179	0,305233	0,002017
ABC	0,629717	0,270158	0,004765

Tabel 5 dan Tabel 6 merupakan hasil perhitungan *error* estimasi lokasi gangguan terhadap berbagai gangguan yang telah disimulasikan. Adapun gangguan yang terjadi berupa AG, BG, CG, AB, AC, BC, ABG, ACG, BCG dan ABC. Pada hasil pengujian dari RNN tipe Elman estimasi lokasi gangguan nilai MAPE pengujian terkecil dihasilkan oleh struktur RNN tipe Elman estimasi lokasi gangguan jenis AG yaitu sebesar 0,245137% baik pada struktur 1 dan 2, sedangkan nilai MAPE terbesar dihasilkan oleh struktur estimasi lokasi gangguan jenis BC yaitu

sebesar 1,017433% pada struktur 1 dan struktur 2 yaitu gangguan jenis ABG sebesar 1,418568%.

IV. KESIMPULAN

Berdasarkan hasil perancangan dan analisa RNN tipe Elman sebagai klasifikasi gangguan dan estimasi lokasi gangguan pada sistem transmisi tenaga listrik dari bus LK, dan BK dapat diambil beberapa kesimpulan. Pertama, pada RNN tipe Elman klasifikasi gangguan yang telah dipilih dapat menentukan adanya gangguan pada masing – masing fasa dan tanah secara benar sesuai dengan jenis gangguan yang terjadi, sehingga akurasi RNN tipe Elman klasifikasi gangguan adalah 100 %. Kedua, rata-rata *error* pengujian yang terendah dihasilkan oleh struktur RNN tipe Elman estimasi lokasi gangguan yang telah dipilih yaitu gangguan 0,245137% baik pada struktur 1 dan 2 jenis AG, sedangkan rata-rata *error* terbesar dihasilkan oleh struktur RNN tipe Elman estimasi lokasi gangguan jenis BC yaitu sebesar 1,017433% pada struktur 1 dan struktur 2 yaitu gangguan jenis ABG sebesar 1,418568%. Dan semua *error* berada dibawah 10% maka RNN tipe Elman sangat baik dalam menentukan estimasi lokasi gangguan pada saluran transmisi dar bus LK dan BK.

DAFTAR PUSTAKA

- A.S, N., & T.S, A. (2017). Smart Fault Location and Fault Classification in Transmission Line. *IEEE*, 339-343.
- Ahmad, S., & Azriyenni. (2019). Klasifikasi dan Estimasi Lokasi Gangguan pada Saluran Transmisi Tenaga Listrik 150 kV Menggunakan Metode Hibrid. *JOM FTEKNIK*.
- Borghetti, A., Bosetti, M., & Paolone, M. (2008). Continuous-Wavelet Transform for Fault Location in Distribution Power Networks: Definition of Mother Wavelet Inferred from Fault Originated Transients. *IEEE Transactions on Power Systems*, 23(2), 380-389.
- Darmawan, S., & Azriyenni. (2018). Identifikasi Gangguan di Saluran Transmisi Tenaga Listrik Berbasis Metode Hibrid. *JOM FTEKNIK*.

- Jamali, S., & Ghaffarzadeh, N. (2011). A new method for arcing fault location using discrete wavelet transform and wavelet networks. *European Transactions on Electrical Power*, 22, 601-615.
- Kusumadewi, S. (2003). *Artificial Intelligence (Teknik dan Aplikasinya)*. Yogyakarta: Andi.
- Mosavi, M., & Tabatabaei, A. (2014). Wavelet and neural network-based fault location in power systems using statistical analysis of traveling wave. *Arab J Sci Eng*, 8, 1-8.
- Otong, M., Alimuddin, & B, C. A. (2017). Deteksi Jarak Lokasi Gangguan Pada Saluran Transmisi 500 Kv Cilegon Baru - Cibinong Menggunakan Adaptive Neuro Fuzzy Inference System (ANFIS). *p-ISSN*.
- Ray, P., & Mishra, D. P. (2016). Support Vector Machine Based Fault Classification and Location of a Long Transmission Line. *Engineering Science and Technology, an International Journal*, 19(3), 1368-1380.
- Rucka, M., & Wilde, K. (2006). Application of continuous wavelet transform in vibration based damage detection method for beams and plates. *Journal of Sound and Vibration*, 297, 536-550.
- Saber, A., Emam, A., & Amer, R. (2016). Discrete Wavelet Transform and Support Vector Machine Based Parallel Transmission Line Fault Classification. *IEEJ Transactions on Electrical and Electronic Engineering*, 43-48.
- Iswadi, H., & Mardiana, R. (2007). Differential Power Transformer Protection Technique Using The Wavelet Packet Transform Approach.